

03-031

## **APPLICATION OF INTELLIGENT SYSTEMS TO QUALITY CONTROL AT PRODUCTION OF SERIAL ITEMS BY MEANS OF THE RECONSTRUCTION OF IMAGES**

*Mula Cruz, Francisco Jose <sup>(1)</sup>; Conesa Pastor, Julian <sup>(1)</sup>*  
<sup>(1)</sup> UPCT

Faced with the current need for an industrial update to the Industry 4.0 model, the need arises to achieve an intelligent system capable of controlling a production chain of parts made of high-value materials to minimize defective parts.

For this reason, a network project is created, based on Machine Learning that acts as distributed control over inferior processes. These nodes in self-control through Machine Learning, interact with each other. Objectives of this work are the use of image reconstruction methods that allow varying the geometric parameters necessary to avoid discarding materials. Previous works and theses have focused on this (Mula, 2016 "Three-dimensional reconstruction of conical perspectives" UPCT and Conesa, 1998 "Reconstruction of pieces in a gentleman's perspective" UPCT). Another objective is to apply Machine Learning techniques for the prediction of results, and create the superior control network. Self-control through Machine Learning has been successfully implemented at the node level, predicting possible variabilities with a very efficient hit rate. This new system translates into time and cost savings, in addition to ensuring the almost nullity of failures once the system performs supervised learning, and is reinforced with validations of new cases.

*Keywords: quality control; reconstruction; A.I. for manufacturing; machine learning*

## **APLICACIÓN DE SISTEMAS INTELIGENTES AL CONTROL DE CALIDAD DE LA PRODUCCIÓN DE PIEZAS EN SERIE MEDIANTE LA RECONSTRUCCIÓN DE IMÁGENES**

Ante la actual necesidad de actualización industrial al modelo de industria 4.0, se plantea la necesidad de conseguir un sistema inteligente capaz de controlar una cadena de producción de piezas, de materiales de elevado valor, para minimizar las piezas defectuosas. Por ello, se crea un proyecto de red, basada en Machine Learning que actúa como control distribuido sobre procesos inferiores. Estos nodos en autocontrol mediante Machine Learning, interactúan entre ellos. Objetivo de este trabajo es usar métodos de reconstrucción de imágenes que permitan variar los parámetros geométricos necesarios para evitar desechar materiales. En ello se han enfocado trabajos y tesis anteriores (Mula, 2016 "Reconstrucción tridimensional de perspectivas cónicas" UPCT y Conesa, 1998 "Reconstrucción de piezas en perspectiva caballera" UPCT). También aplicar técnicas de Machine Learning para la predicción de resultados, y crear la red de control superior. Este nuevo sistema se traduce en un ahorro de tiempo y costes, además de asegurar la casi nulidad de fallos una vez que el sistema realiza el aprendizaje supervisado, y se refuerza con validaciones de nuevos casos.

*Palabras clave: control de calidad; reconstrucción; sistemas inteligentes de la producción; machine learning;*

Correspondencia: Francisco José Mula Cruz    pacomula@yahoo.com



©2020 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

## 1. Introducción

Atendiendo a la Excelencia Operacional, que actualmente está en plena demanda en todo el entramado de industrias 4.0., y conociendo la necesidad de respuesta de la industria al reto de optimizar la fabricación de piezas en serie cuya materia prima es de elevado coste, se nos hizo necesario crear un proyecto tecnológico para dar respuesta a ello.

El principal problema que se tropiezan este tipo de empresas que han de optimizar su cadena de producción, es evitar rechazos de fabricación, por lo que nos planteamos realizar el proyecto basado en una red de autoaprendizaje en el Machine Learning (ML).

Si pensamos por un momento en el alto volumen de datos que genera la fabricación y controles de calidad intermedios hasta la consecución de un producto final, como son tolerancias de medidas en diferentes tipos de fabricación y materiales, ajustes de montaje, pruebas parciales y finales, etc., es una cantidad ingente de información que, en muchas ocasiones, no está integrada en los departamentos técnicos de la empresa, por lo que se pierde la visión de conjunto aunque esté debidamente recogida informáticamente o digitalizada.

Esta información difusa y extensa, bien por falta de recursos, tiempo, costes, o lo que es más habitual, una combinación de todos esos factores, complican la toma de decisiones, la hacen imprecisa o errónea, y sujeta en gran parte a ideas u opiniones subjetivas basadas cuanto más en una experiencia anterior no debidamente sustentada en muchos casos.

Además, las cadenas de producción están basadas en máquinas y recursos que no siempre funcionan con un 100% de fiabilidad y de ajuste en su fase de producción, generando pequeñas variaciones aleatorias no esperadas que influyen en las siguientes etapas productivas y que, al final del proceso, resultan en la incertidumbre de la validez del producto final con las consiguientes pérdidas asociadas.

Como sabemos, las personas carecen de la capacidad de análisis en tiempo real de toda esa información y variabilidades, lo que impide obtener resultados óptimos y una mejora continua del proceso, siendo para ello necesario utilizar una de las herramientas que ha demostrado ser una potente funcionalidad de mejora en este tipo de escenarios como es el ML.

El ML es considerada incluso por la consultora Gartner como “una de las 10 tecnologías estratégicas que revolucionará las empresas y que supondrá un cambio de paradigma en la forma de producir de las fábricas”. Incluso la multinacional General Electric, la califica como “la base de la Cuarta Revolución que impulsará la capacidad de producción hasta un 20%, y que generará importantes ahorros en consumo de material y gasto energético, reduciendo también en un 20% los retrabajos”.

Como describen algunos autores (Monleón-Getino ,2010 y 2018, Kovahi y Provost, 1998), la ML se define como una disciplina proveniente de las ciencias y la ingeniería que se ocupa de la construcción y el estudio de los algoritmos que pueden aprender a partir de datos. Los algoritmos ML intentan construir modelos basándose en datos, con el objetivo de hacer predicciones o tomar decisiones como si se tratasen de verdaderos expertos, en lugar de seguir de manera explícita las instrucciones para las que han sido programados (Bishop, 2006). Las técnicas de ML que se revisan ampliamente en trabajos recientes (James & Al, 2013) proceden de campos como la Estadística, Reconocimiento de Patrones, Inteligencia Artificial y Minería de Datos.

En este proyecto, partiendo de los parámetros obtenidos a partir de imágenes de piezas complejas, se implementa una red de aprendizaje apoyada en ML para la mejora de los procesos de calidad en fabricación de piezas en una cadena de producción.

## 2. Objetivos

Los objetivos principales y necesarios del proyecto son:

- 1.- obtener la imagen de la pieza fabricada y leer unos parámetros preestablecidos de la misma, detectando las posibles desviaciones fuera de la tolerancia inicial prevista,
- 2.- realizar el aprendizaje sobre la casuística de variaciones presentadas sobre esos parámetros,
- 3.- en base al aprendizaje, crear una predicción viable para resolver la viabilidad de la pieza en otras diferentes situaciones que, muy posiblemente, se pueden producir en el futuro en el proceso de fabricación,
- 4.- crear para controlar todos los procesos de fabricación una red de nodulos o procesos menores interdependientes que sea capaz de controlar su propio proceso parcial e interactuar con los otros para conseguir optimizar los resultados de la cadena completa hasta el producto final acabado.

## 3. Metodología

La metodología empleada es, fundamentalmente, la obtención de parámetros a controlar y, posteriormente, aplicar las técnicas de ML en diferentes nodos, implementados en una red general del proceso, basada igualmente en ML.

### 3.1 Análisis de las posibilidades de implementación del Machine Learning

Para comenzar, y antes de aplicar las técnicas de ML, es necesario obtener un modelo tridimensional a partir de una imagen o varias obtenidas por una cámara.

Con ello obtenemos los parámetros a controlar que se buscan para que la pieza sea válida.

En un trabajo previo (Conesa & Mula, 2016) presentamos una arquitectura basada en multiagentes para la reconstrucción de modelos fotografiados, es decir, para la obtención de un modelo tridimensional a partir de una fotografía. La arquitectura propuesta en ese trabajo partía de fotografías que tras la vectorización ofrecían el grafo del modelo en perspectiva cónica paralela y oblicua. Posteriormente, estos grafos eran convertidos en modelos tridimensionales tras aplicarles los algoritmos propuestos.

En posteriores trabajos se amplió la reconstrucción de imágenes a figuras más complejas y se implementaron técnicas basadas en esta misma arquitectura, añadiendo otra serie de algoritmos para la reconstrucción de huesos a partir de una radiografía mediante aplicaciones de poblaciones estándar, etc. (Mula & Conesa, 2018).

Estas técnicas de reconstrucción contemplaban la posibilidad de obtener, por elementos o por matrices de puntos, la discretización de las imágenes reales de piezas complejas.

Usando como base esa obtención de parámetros geométricos de la pieza, en el proyecto.

Una vez obtenida la geometría y por ende los parámetros a controlar, es el momento de aplicar las técnicas de ML.

Mediante el, como se suele llamar, aprendizaje supervisado, se propone una batería de posibles casos de piezas digitalizadas con defectos, tolerables o no, y se dota al sistema de las soluciones válidas.

En base a ello, el sistema se vuelve capaz de decidir y proponer la solución correcta.

En caso de que la tasa de acierto no alcance a responder correctamente a algún caso concreto, se va corrigiendo al sistema, creando un sistema más robusto y fiable en el tiempo. Esto es conocido como aprendizaje de refuerzo.

### **3.2 Uso de familias de elementos a controlar basados en tipologías preasignadas**

Nuestro primer objetivo se centra en la reconstrucción de la imagen para poder realizar patrones comparativos que constituyan la fuente de datos para ser tratados mediante la aplicación de ML.

- Un primer paso es decidir el tipo de obtención de datos de una imagen en función de la fisonomía de las piezas a controlar. Para ello, se diferencian familias de piezas que inducen a elegir el método de obtención de imagen para su posterior tratado y obtención de los parámetros a controlar, en base a desviaciones en las comparativas de un patrón fundamental.
- Obtenidos los parámetros en la instancia definida a controlar del proceso productivo, se emplean técnicas de ML con varios tipos de regresiones en función del número de variables, población, etc., ofreciendo por un lado la predicción de posibles fallos en la producción en relación al producto final, y por otro lado, el ajuste de parámetros necesarios para mantener las desviaciones dentro de las tolerancias de fabricación establecidas por la empresa para cada familia de piezas y posteriores interrelaciones con el resto de la cadena de montaje.

Este tipo de solución es válido principalmente en el proceso producción donde residen los mayores problemas de eficiencia (cuellos de botella). Los procesos adquieren inteligencia en base a los hallazgos y mejoras anteriores que se han realizado y, posteriormente, conducen a una optimización holística de todo el proceso de fabricación.

### **3.3 Detección primera de resultados en las superficies de acabado**

La obtención de parámetros mediante la digitalización de imágenes es un problema complejo que, en nuestro caso, mediante la aplicación de los algoritmos desarrollados en los trabajos anteriormente citados y que pueden ser aplicados a una gran familia de piezas, se reduce a la definición de aristas, caras, etc., y en base a ello, simplificamos en parte el proceso de obtención de desviaciones del estándar requerido inicialmente.

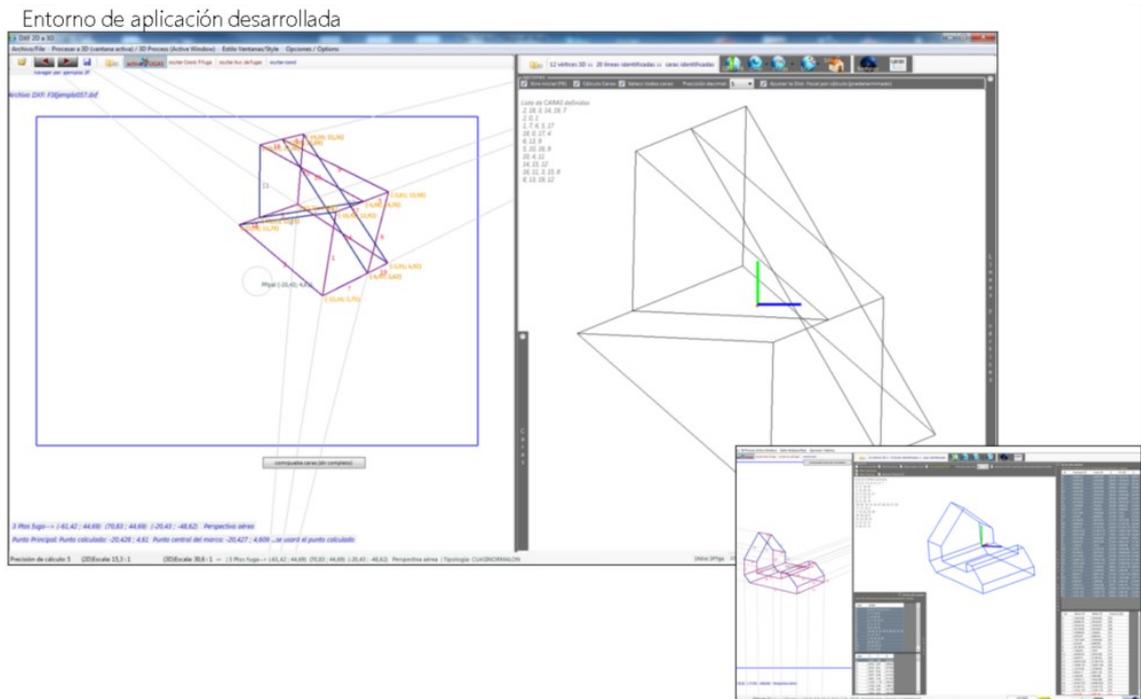
Este problema inicial para obtener la reconstrucción tridimensional ya fue abordado con anterioridad (Conesa & Mula, 2016), como hemos mencionado anteriormente.

La diferencia de esta forma de resolución mediante el algoritmo creado, con respecto a la obtención de una nube de puntos, es, básicamente, que se consiguen los elementos geométricos que componen la figura, es decir, aristas, caras, vértices, etc.

Esa representación espacial en CAD (Figura 1), basada en elementos de líneas y caras obtenidas ha permitido fácilmente poder medir los parámetros requeridos, tales como, por ejemplo, el paralelismo de caras críticas de la pieza, longitudes de aristas, perpendicularidades, e incluso ángulos y diedros.

En la actualidad hay otros usos de técnicas similares en otros campos, como por ejemplo el de la medicina, donde, por las características de la obtención de imágenes, ha de usarse el big data obtenido de una nube de puntos de una imagen en 3D para, entonces, reconstruirla por puntos, y proceder a clasificar partes de la propia imagen, de acuerdo a unos parámetros de validez (Gómez, 2018).

**Figura 1: Aplicación de reconstrucción de figuras a partir de su grafo**



En este proyecto hacemos uso de la técnica de clasificación para para los parámetros a controlar a partir de la reconstrucción obtenida en 3D de la pieza.

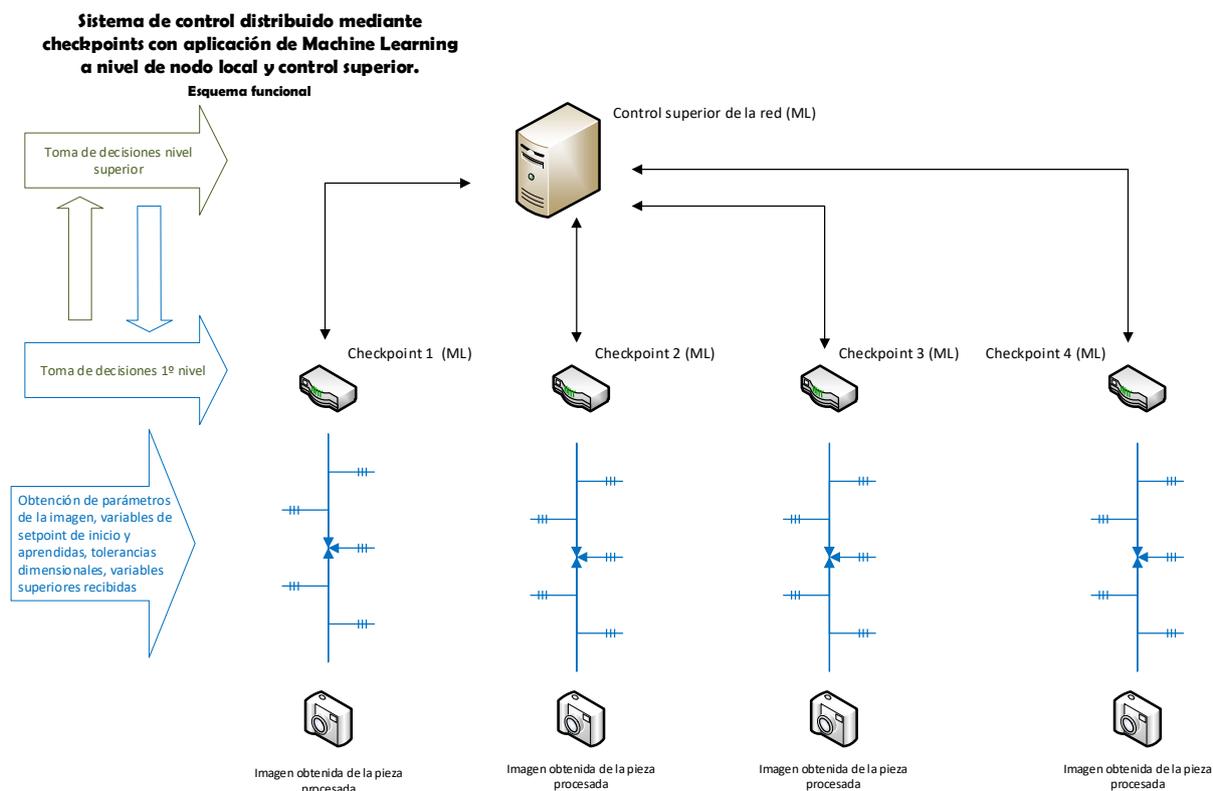
Además de eso, y a diferencia de otros trabajos dentro de este ámbito, se ha creado, como hemos comentado, una cadena de nodos, o como empezaremos a llamar, “checkpoints”, a modo de “puntos de espera” para la obtención de parámetros en los diferentes pasos o estadios. Estos checkpoints serán regidos por un sistema superior que actúe como controlador y concluya en la proposición y toma de decisiones compuesta en base a los resultados obtenidos de los diferentes checkpoints de la cadena.

En el siguiente esquema (Figura 2) vemos gráficamente el proceso de control establecido. En el funcionamiento del proceso, los resultados de la aplicación de aprendizaje y predicción mediante la aplicación de Machine Learning a nivel de checkpoints (1º nivel) son aportados a modo de soluciones parciales al sistema de control superior, que es el que a su vez controla a todos los nodos de 1º nivel.

En ese nivel superior se aplica de nuevo el ML pero integrando el resto de checkpoints en el algoritmo, en base a los resultados obtenidos, y en beneficio del conjunto del sistema modifica, valida o niega las decisiones parciales recibidas inicialmente de cada checkpoint.

Estas consignas son enviadas a cada checkpoint y son ingresadas como variables de setpoint a incluir en el algoritmo y proceso de aprendizaje.

Figura 2: Esquema funcional



Un primer parámetro sencillo a controlar en la cadena de producción, es la salida de fabricación de una pieza para su posterior ensamblado con el resto.

En este primer checkpoint se determina la validez del acabado superficial de las piezas en base a la digitalización de imágenes de las mismas, para posteriormente compararlas con un patrón de tolerancias inicial previamente establecido, y del cual se conoce su validez.

A partir de ahí, se introducen variaciones a ese patrón inicial y se deja al sistema predecir los resultados que se obtendrán de esos cambios.

En el proceso de aprendizaje, el algoritmo del sistema va obteniendo el porcentaje de aciertos derivados de la decisión de aceptación de este proceso inicial según la superficie, proponiendo cambios en base al análisis en tiempo real de las ingentes posibilidades de aceptación de defectologías superficiales y tolerancias admitidas.

En un segundo checkpoint, el sistema se alimenta de la validación que los cambios propuestos al siguiente checkpoint.

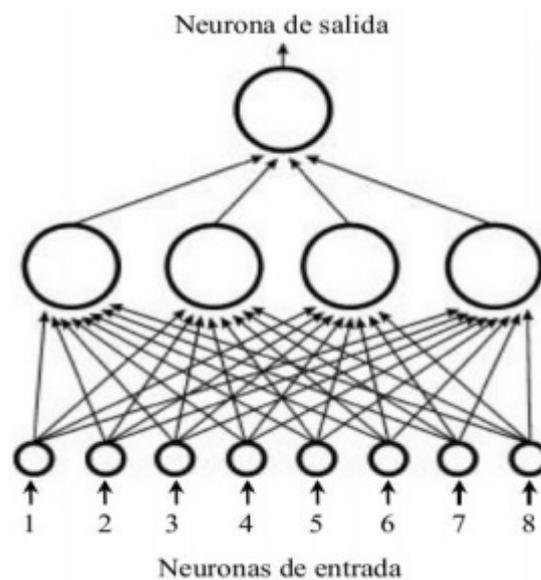
Con la implementación de los diversos checkpoints definidos en el proceso, se establece una red general a modo de red neuronal basada en nodos (checkpoints) que a su vez están trabajando como multiagentes inteligentes de mejora para el sistema central de control.

Actualmente, el trabajo que estamos desarrollando se sitúa en el primer escalón de desarrollo, que pasa por la aplicación del ML para la toma de decisiones en los diferentes checkpoints, para posteriormente poder pasar a una integración total de ellos en un solo sistema superior que proponga cambios de estandarizaciones, optimice los materiales y sea

capaz de, en base al análisis de las desviaciones de la producción, tomar las decisiones oportunas para que el producto final cumpla los estándares de funcionalidad y de calidad requeridos como base fundamental del proceso.

Este ensamblado final implementado actúa a modo de red neuronal, donde la neurona de salida (Figura 3) sería el nivel superior de control mencionado, actuando de forma similar a una red neuronal artificial (RNA) que constituye un modelo computacional que simula algunas formas del funcionamiento del cerebro humano, sin llegar a desarrollar una réplica del mismo (Written, 2005).

**Figura 3: RNA (red neuronal artificial)**



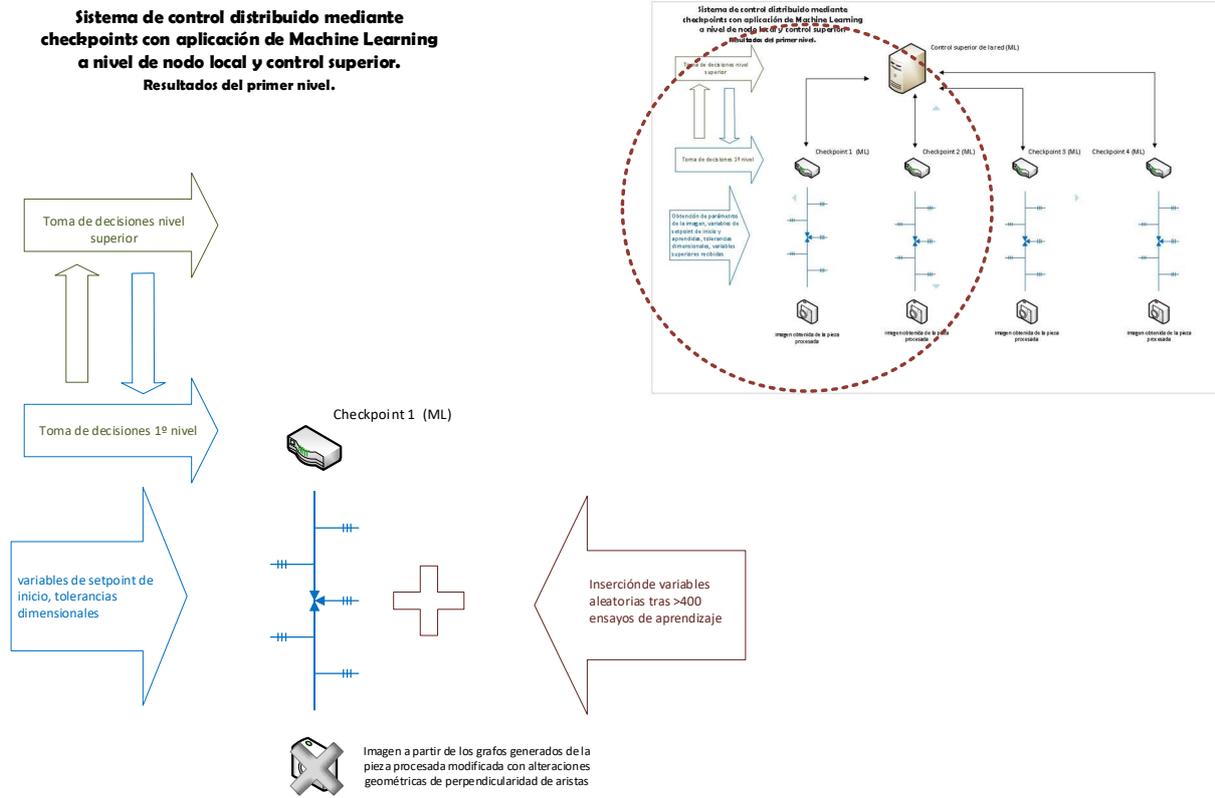
#### **4. Resultados preliminares**

Basado en los conocimientos obtenidos de la Universidad de Standford en cuanto a la aplicación de ML, y al resto de investigaciones abiertas en este campo, hemos conseguido que primeramente el sistema aprenda en base a una tasa impuesta de validaciones para las piezas en su primer escalón de estado superficial.

Primeramente, se modificaron varios parámetros geométricos conocidos, introduciéndolos arbitrariamente en la fase de obtención de la pieza por mecanizado asistido (CAM).

Dado que en la fase de aprendizaje del sistema es necesario ensayar un conjunto de casos para evaluar la efectividad del acierto del sistema, y con el objetivo de evitar la fabricación de todos los modelos a ensayar, se introdujeron los cambios directamente mediante la parametrización de las imágenes obtenidas, siendo estos cambios el punto de partida del proceso (Figura 4).

**Figura 4: Implementación a primer nivel**



El parámetro modificado para trabajar con este sistema ha sido la perpendicularidad de varias aristas de la pieza. Tras ensayar un conjunto de casos iniciales (>400) indicándole al sistema el conjunto de resultados válidos, ha sido posible que, al introducir nuevas variaciones aleatorias de perpendicularidad entre aristas, el sistema realice la predicción del resultado, y en función de él, ajuste la tolerancia máxima aceptable para cada caso, consiguiendo en tiempo real la propuesta de modificación en el ajuste de la tolerancia del mecanizado (Figura 3).

Realizados los correspondientes ensayos, y realimentando el proceso a ese primer nivel con las variables booleanas de validaciones, el sistema es capaz de predecir los resultados en diferentes hipótesis planteadas en cuanto a variaciones aleatorias no esperadas, obteniendo un porcentaje cercano al 95% de acierto en tiempo real. Para ello, se contabilizaron las predicciones de acierto que arrojó el sistema en diferentes tandas de ejemplos, y se obtuvo la media de los resultados. Esas tandas de ejemplos fueron propuestas al sistema mediante conjuntos de casos con diversas variaciones aleatorias creadas voluntariamente sobre de los grafos.

Los resultados obtenidos se han comparado con la validez de las decisiones obtenidas ante las diversas variaciones introducidas arbitrariamente al sistema y su influencia en el siguiente checkpoint del proceso de fabricación.

Nuestro trabajo futuro dentro de este ámbito, una vez realizado el proceso de aprendizaje en los diferentes checkpoints y con diferentes parámetros geométricos, y comprobado y validado el porcentaje de acierto en cada uno de ellos, se centra en ascender al nivel superior donde las variables del aprendizaje son las propias decisiones del nivel inferior validadas, pero con el objetivo de la validación y optimización del producto.

Este sistema propuesto es escalable, permitiendo crecer en base a sistemas paralelos o en red neuronal que puedan contemplar decisiones de producción añadiendo variables discretas relacionadas con inputs de información de otros ámbitos tales como materiales, stock, prioridades, etc., ofreciendo en tiempo real la optimización de todos los procesos productivos implicados en la industria.

## 5. Conclusiones

La aplicación de técnicas de I.A. como el ML a los procesos de fabricación realizados en este trabajo, lleva al entramado productivo de la empresa a un nivel superior dotándola de unas capacidades alineadas con el desarrollo de la industria 4.0.

Con el presente trabajo se consigue impulsar la capacidad de producción sostenible, generando importantes ahorros en consumo de tiempo, material y gasto energético, reduciendo drásticamente los reprocesos.

### 5.1 Limitaciones del proyecto y futuras líneas de desarrollo

En este trabajo hemos planteado el siguiente estadio de mejora en un proceso productivo complejo basado en una arquitectura similar a un sistema de control distribuido, pero controlado jerárquicamente por un sistema de aprendizaje central que coordina la red inferior.

Actualmente, en el proyecto se ha desarrollado una primera fase de aplicación de ML a los nodos o checkpoints de una red de control distribuido del proceso.

Las líneas futuras de actuación apuntan claramente al ensamblaje y aprendizaje integrado de todos los posibles nodos, intercambiando entre ellos información por ale aprendizaje, así como el diseño de la red superior que ha de controlarlos a todos y, estando también basada en el ML, proporcionar mayor tasa de acierto y fiabilidad al sistema.

### 5.2 Trabajos actuales en desarrollo, relacionados con este proyecto

En la actualidad existen trabajos similares al presentado en esta comunicación, como es el caso de del proyecto Talent del Centro Tecnológico de Investigación, Desarrollo e Innovación en tecnologías de la Información y las Comunicaciones (TIC) de Valencia iniciado en 2017, que hasta ahora se centra en la obtención de parámetros de una serie de piezas fabricadas para su validación.

Paralelamente, hay una serie de desarrollos en las líneas de nuevos materiales que también podrán hermanarse con el control de calidad del presente estudio para que la arquitectura de control disponga de un sistema de aprendizaje más complejo, incluyendo no solo la calidad de la fabricación sino los tipos de materiales a emplear para optimizar el resultado. En este ámbito han colaborado diversas entidades internacionales como:

- **Investigadores de Northwestern** utilizaron IA para desarrollar un nuevo vidrio metálico, un material que tiene aplicación en dispositivos inteligentes y en la industria aeroespacial.
- **Investigadores del MIT** desarrollaron una red neuronal para analizar un conjunto de datos de entrenamiento con el fin de encontrar patrones para crear recetas más eficientes y rentables y descubrir nuevos materiales.
- **Equipo de la Universidad de Stanford** utilizó ML para desarrollar electrolitos mejorados para baterías de iones de litio. Los resultados actuales muestran que el modo de ML supera a los expertos en sus predicciones.

- **Investigadores de Maryland** están utilizando ML para la investigación y la evaluación de los superconductores.
- **Investigadores japoneses** utilizaron un sistema de IA, inicialmente desarrollado para videojuegos, para analizar y explorar el diseño de estructuras de aleación de silicio-germanio más eficiente térmicamente.

## Referencias

- Conesa, J. & Mula, F. (2016). An agent-based paradigm for the reconstruction of conical perspectives. *Expert Systems With Applications* (55), 1-20, DOI information: 10.1016/j.eswa.2016.02.003
- Bishop. (2006). *Pattern Recognition and Machine Learning*. Springer
- Foster Kevin, (2011) Nathan Senthil, Rajan Deepak, Ballard Chuck, IBM *InfoSphere Streams: Assembling Continuous Insight in the Information Revolution*, IBM RedBooks.
- Gómez Valenzuela, C. (2018) “*Machine Learning para caracterizar ARNs circulares en exosomas de sangre periférica como biomarcadores*” Fin de Máster de Univ. Abierta de Cataluña.
- James & AI, (2013). *An Introduction to Statistical Learning: with Applications in R*
- Monleón-Getino, A. (2010). *El tratamiento numérico de la realidad. Reflexiones sobre la importancia actual de la estadística en la sociedad de la información*. Arbor, Vol 186, No 743.
- Monleón-Getino, A. (2018). *El impacto del Big-data en la Sociedad de la Información. Significado y utilidad*.
- Mula, F. & Conesa, F. (2018) “*Reconstrucción de un hueso de tibia a partir de una radiografía*”. AEIPRO, International Congress on Project Management and Engineering, Madrid.
- Ron Kovahi; Foster Provost. 1998. “*Glossary of terms*”. *Machine Learning* 30: 271–274
- Witten I, Frank E. (2005) “*Practical machine learning tools and techniques*”. San Francisco, Estados Unidos de América: Morgan Kaufmann;

## Comunicación alineada con los Objetivos de Desarrollo Sostenible

